

Reorientación automática de imágenes SPECT de perfusión miocárdica

Automatic reorientation of myocardial perfusion SPECT images

Presentación: 02/08/2024

Doctorando:

Ezequiel VIJANDE

Diagnóstico Nuclear, Comisión Nacional de Energía Atómica, Facultad Regional Buenos Aires, Universidad Tecnológica Nacional - Argentina
evijande@frba.utn.edu.ar

Director:

Mauro NAMÍAS

Resumen

Las imágenes SPECT de perfusión miocárdica brindan información sobre el flujo sanguíneo del músculo cardíaco. Previo a ser interpretadas por un cardiólogo nuclear, las imágenes deben ser reorientadas a lo largo del eje largo del corazón. Esto suele realizarse de manera manual, siendo un proceso dependiente del operador y por lo tanto de reproducibilidad limitada. En este trabajo proponemos un método de reorientación automático utilizando una red neuronal convolucional para predecir las posiciones de la base, ápice y centro del ventrículo derecho a partir de las imágenes adquiridas. El modelo fue entrenado a partir de imágenes y anotaciones elaboradas por dos profesionales distintos. Los resultados obtenidos fueron comparados con los errores inter e intra operador, y de esta manera se pudo confirmar que el método propuesto logra un rango de error al menos tan bueno como el de los métodos manuales.

Palabras clave: perfusión miocárdica, reorientación automática, aprendizaje profundo, SPECT

Abstract

Myocardial perfusion SPECT imaging supplies information about the blood flow in the cardiac muscle. Images must be reoriented with respect to the heart's long axis before they can be interpreted. This step is usually performed manually, which means the process is operator-dependent and thus suffers from limited reproducibility. In this work we propose an automatic reorientation method by using a convolutional neural network in order to predict the location of the base, apex and center of the right ventricle from the acquired images. Training of the model was performed from images labeled by two different professionals. Results were compared with the inter and intra observer variabilities, verifying that the error range of the proposed method is within the same bounds as for the manual case.

Keywords: myocardial perfusion, automatic reorientation, deep learning, SPECT

Introducción

Las imágenes SPECT de perfusión miocárdica con ^{99m}Tc -Sestamibi juegan un rol fundamental en el diagnóstico de la enfermedad coronaria, siendo una modalidad semi-cuantitativa. El proceso de análisis cuantitativo de estudios de perfusión miocárdica consiste en varias etapas en el procesamiento de los datos adquiridos. Desde la reconstrucción, la reorientación y la segmentación hasta la generación de los mapas polares, la comparación con límites normales y el cálculo final de los parámetros clínicos cuantitativos (Germano & Berman, 2006, 69-70).


En este trabajo nos centramos en la etapa de reorientación desde los cortes transaxiales a los ejes cardíacos (eje largo vertical, eje largo horizontal y eje corto). Esto requiere en general determinar de manera manual la posición central de la base del miocardio, el ápice y el centro del ventrículo derecho. Pueden encontrarse un número de trabajos publicados recientemente sobre el desarrollo de herramientas de reorientación automáticas y basadas en redes neuronales (Zhang et al., 2021) (Zhu et al., 2023). A diferencia de trabajos previos, el método propuesto utiliza una arquitectura 3D U-Net (Çiçek et al., 2016) para realizar la ubicación de la base, el ápice y el centro del ventrículo derecho en lugar de directamente producir las imágenes reorientadas. Adicionalmente, realizamos una estimación de la variabilidad resultante del alineamiento manual por dos operadores humanos distintos así como entre un mismo operador con un lapso de 3 meses entre alineamientos.

Encontramos que el método propuesto logra la ubicación de las tres referencias anatómicas con una precisión comparable a la que se obtiene de un operador humano. También, que las variabilidades inter e intra operador en la reorientación pueden generar diferencias en los valores de captación de los segmentos del mapa polar de $\pm 15\%$ y que las diferencias entre el método manual y el automático también están contenidas dentro de este rango.


Desarrollo

Se entrenó una red neuronal de arquitectura 3D U-Net como predictor de las coordenadas espaciales de la base, el ápice y el ventrículo derecho a partir de imágenes de perfusión miocárdica SPECT adquiridas con el radiofármaco ^{99m}Tc -Sestamibi. Para el entrenamiento se utilizaron versiones aumentadas con rotaciones, traslaciones y cambios de contraste de 128 estudios SPECT. Del total de estudios, 48 fueron adquiridos utilizando un equipo híbrido SPECT/CT reconstruidos aplicando correcciones por atenuación basada en la tomografía computada, de aquí en más referidos como los estudios AC. Mientras que los 80 estudios restantes fueron adquiridos con un equipo GE Ventri sin corrección por atenuación, de aquí en más referidos como los estudios NAC.

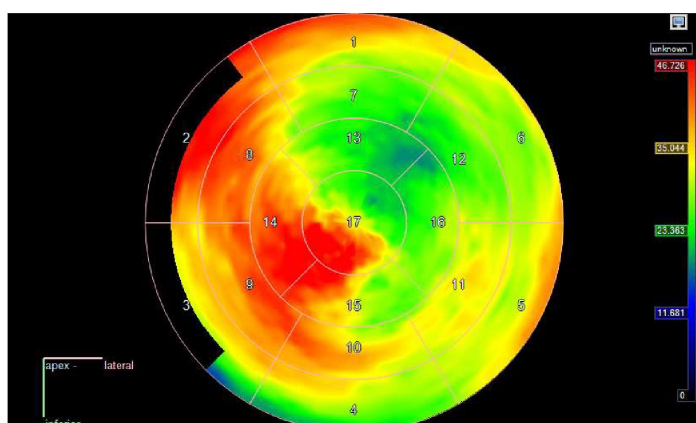
El ensayo final se realizó sobre 30 estudios adicionales, 15 con corrección por atenuación y 15 sin. Todos los estudios fueron etiquetados por dos expertos. El software CARIMAS 2.10 (Rainio et al., 2023) fue utilizado para etiquetar las imágenes, al igual que para realizar la segmentación del ventrículo izquierdo y la generación de mapas polares cardíacos de 17 segmentos (Figura 1).



a.



b.



c.

Figura 1. Interfaz del software CARIMAS donde se cargan los estudios SPECT. En cada imagen se muestra una parte del flujo de procesamiento ordenadas secuencialmente. La subfigura a. corresponde al paso de reorientación donde el experto realiza la selección de las tres referencias anatómicas. En b. se visualizan los cortes cardiacos luego de aplicada la reorientación y un algoritmo de segmentación automática define la máscara del ventrículo izquierdo que puede ser refinada manualmente por el observador. Finalmente en c. se calcula el mapa polar generado a partir de los resultados de la segmentación, en este paso se pueden exportar los valores de captación obtenidos en cada uno de los segmentos.

A partir de las referencias anatómicas seleccionadas por los expertos se generaron imágenes en formato nifty con la ubicación de cada una en un canal distinto de la imagen. Para mitigar el problema de la baja resolución de las imágenes SPECT, se utilizó el método de interpolación de volúmenes parciales (Maes et al., 1997). El método consiste en guardar información espacial de cada referencia en su canal correspondiente como un cubo tridimensional de 8 voxels adyacentes. Cada uno de estos voxels guarda el valor de un peso proporcional a la distancia euclidiana entre la ubicación espacial de la referencia y el centroide del voxel. De esta forma se conserva la resolución subvoxel lograda por la interpolación del software CARIMAS que trabaja con una versión escalada a un mayor tamaño de las imágenes SPECT.

Los nuevos archivos nifty generados se utilizan como anotaciones de referencia para el entrenamiento y para el cálculo de métricas finales sobre el conjunto de prueba. Las inferencias del modelo 3D U-Net fueron transformados inversamente desde los archivos nifty a los valores de coordenadas espaciales interpolados y almacenados en un archivo XML bajo el formato necesario para ser cargados como un proyecto de CARIMAS. De esta forma, tanto el caso manual como el automático pasaron por el mismo algoritmo de segmentación y cálculo de mapas polares automático de CARIMAS.

Se calculó el error relativo por segmento entre los mapas polares obtenidos a partir de la orientación manual y aquellos obtenidos a partir de las predicciones sobre el conjunto de pruebas. Adicionalmente, el profesional que etiquetó los datos AC utilizados para el entrenamiento volvió a etiquetar los 30 estudios del conjunto de prueba unos 3 meses más tarde y se compararon las diferencias entre los casos de predicción automática, interoperador e intraoperador mediante la prueba de los signos para datos emparejados.

Resultados

Como puede observarse en la Tabla 1, el método propuesto sobre AC resultó ser aquel con el menor error relativo medio en las captaciones por segmento observadas en el mapa polar, seguido del caso intraoperador, el método propuesto sobre NAC y por último el caso interoperador.

Comparación	μ	σ	MAE
Op1 vs Op1 (AC)	0.24%	8.62%	5.60%
Op1 vs Op2 (NAC)	3.38%	7.14%	5.21%
3D-UNet vs Op1 (AC)	0.19%	7.53%	5.40%
3D-UNet vs Op2 (NAC)	1.27%	5.11%	3.60%

Tabla 1. Medias, desviaciones estándar y error medio absoluto (MAE) de los errores relativos tomando la diferencia entre los valores de captación por segmento del método y el etiquetado final realizado por el operador 1. Cada fila se calculó calculando las diferencias de los 17 segmentos sobre 15 los estudios de prueba AC o NAC según corresponda (n=255)




Figura 2. Regresión lineal de las coordenadas para cada uno de los ejes del volumen.

La variabilidad interoperador demostró ser significativa para 6 de los 18 segmentos (17 segmentos + global) y para 2 de las 9 coordenadas ($p < 0.05$). En el caso de la variabilidad intraoperador, 2 segmentos y 1 coordenada fueron estadísticamente significativos ($p < 0.05$). Los errores de la predicciones de la red sobre NAC no demostraron ser significativos para ningún segmento ni coordenada ($p > 0.1$). Mientras que las predicciones sobre AC solo 1 coordenada tuvo error significativo y ningún segmento ($p < 0.05$).

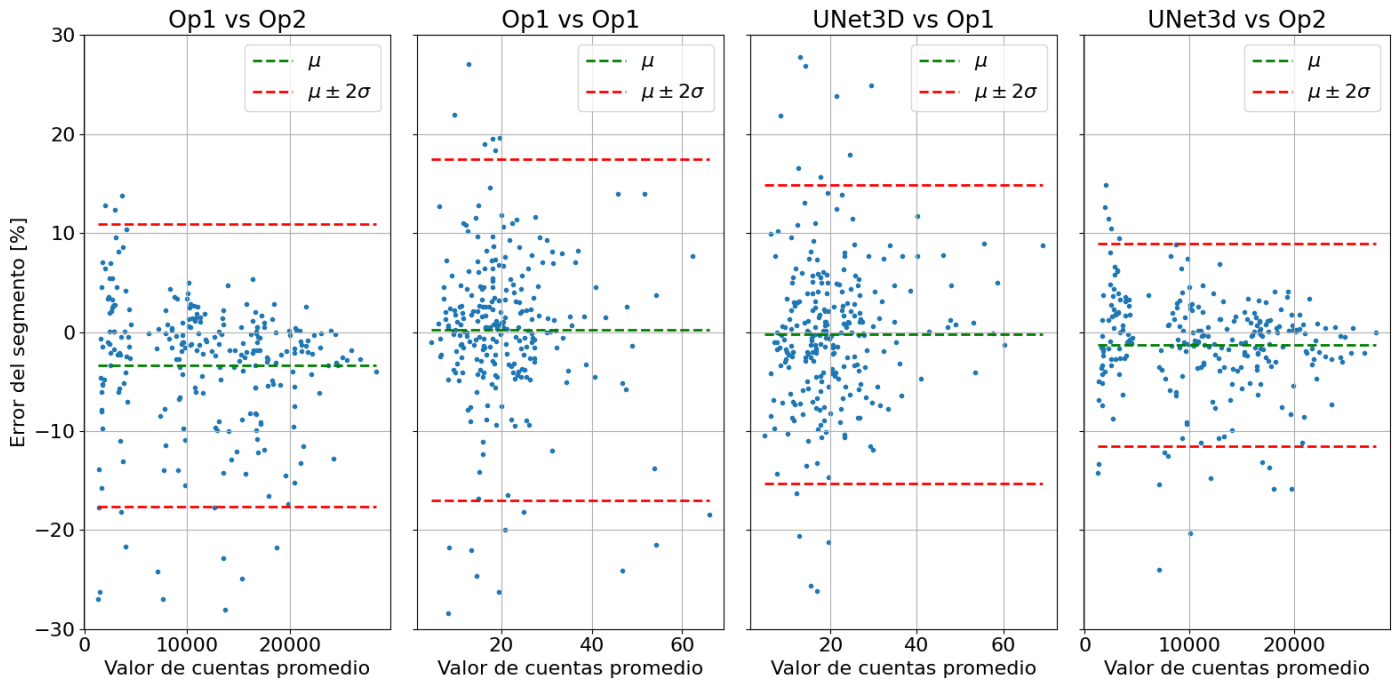


Figura 3. Gráficas de Bland Altman (Bland, J. M., & Altman, D. G., 1986) de las diferencias relativas en los valores de perfusión por segmento. En cada gráfica se visualizan las diferencias entre operadores, entre el mismo operador en momentos distintos o entre el modelo automático y un operador. La diferencia de escala en los valores de cuentas entre ambas gráficas se debe a que el conjunto de datos de la gráfica derecha es sobre los datos AC y la izquierda sobre los NAC.

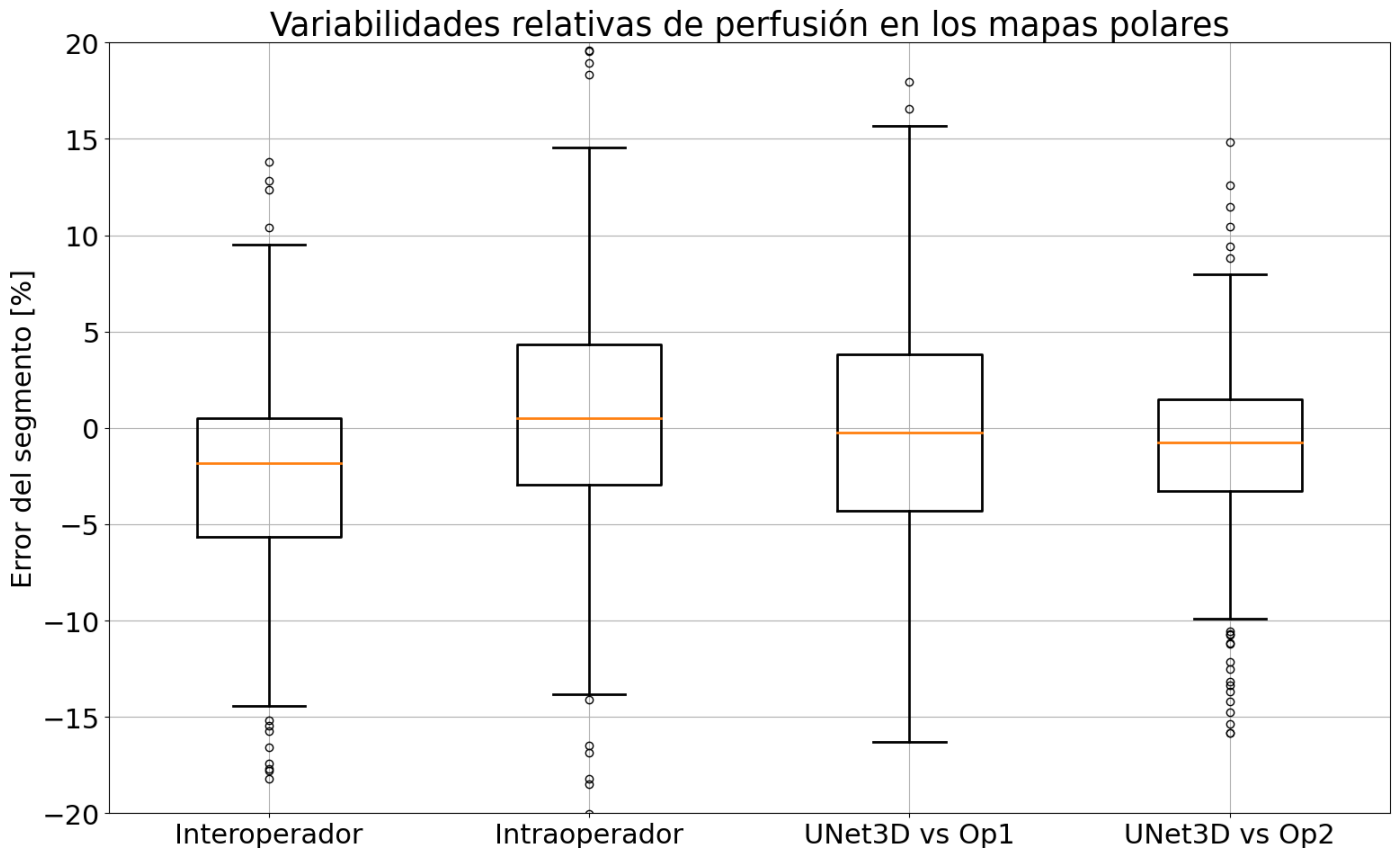


Figura 4. Gráficas de boxplot de los errores relativos por segmento. Los boxplots correspondientes a los extremos se calcularon sobre los datos NAC del conjunto de prueba. Mientras que los dos boxplots centrales, se calcularon sobre los datos AC del conjunto de prueba.

A partir de la figura 2 se puede ver que existe una alta correlación entre las predicciones automáticas y las anotaciones manuales ($R^2 \geq 0,98$ para los tres ejes). Como puede apreciarse en las figuras 3 y 4, las predicciones del modelo muestran errores en el mismo rango o menor que las comparaciones inter e intra operador, tanto en los valores por segmento. Esto parece indicar que el método propuesto es al menos tan bueno como un operador humano profesional con la ventaja de que el método automático siempre tiene la misma consistencia y reproducibilidad en sus predicciones.

Conclusiones

La arquitectura 3D U-Net utilizada es capaz de predecir de manera automática las posiciones de la base, ápice y ventrículo derecho con errores milimétricos para la mayoría de los casos. El error en la orientación automática da indicios de estar al menos en el mismo orden que el error interoperador tanto como el intraoperador, $\pm 15\%$ en los valores de captación por segmento en todos los casos.

Existen limitaciones al comparar entre los resultados intra e inter operador así como también para los datos AC y NAC dado que ambos casos pertenecen a estudios distintos realizados sobre distintos pacientes. Asimismo, la baja cantidad de estudios para cada uno de los conjuntos de ensayo limita la robustez y cantidad de análisis estadísticos que pueden realizarse sobre los resultados obtenidos. Aun así, los resultados del modelo propuesto son prometedores cuando se comparan las predicciones realizadas con las anotaciones manuales sobre un mismo conjunto de datos. Queda pendiente la validación del análisis en ensayos con un mayor número de estudios y de operadores humanos.

Referencias

- Bland, J. M., & Altman, D. G. (1986). Statistical methods for assessing agreement between two methods of clinical measurement. *Lancet (London, England)*, 1(8476), 307–310.
- Çiçek, Ö., Abdulkadir, A., Lienkamp, S.S., Brox, T., Ronneberger, O. (2016). 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. In: Ourselin, S., Joskowicz, L., Sabuncu, M., Unal, G., Wells, W. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016*. MICCAI 2016. Lecture Notes in Computer Science(), vol 9901. Springer, Cham. https://doi.org/10.1007/978-3-319-46723-8_49
- Germano, G., & Berman, D. S. (Eds.). (2006). *Clinical Gated Cardiac SPECT*. New Jersey: Wiley.
- Maes, F., Collignon, A., Vandermeulen, D., Marchal, G., & Suetens, P. (1997). Multimodality image registration by maximization of mutual information. *IEEE transactions on Medical Imaging*, 16(2), 187–198.
- Rainio, O., Han, C., Teuvo, J. et al. Carimas: An Extensive Medical Imaging Data Processing Tool for Research. *J Digit Imaging* **36**, 1885–1893 (2023). <https://doi.org/10.1007/s10278-023-00812-1>
- Zhang, D., Pretorius, P.H., Lin, K. et al. A novel deep-learning-based approach for automatic reorientation of 3D cardiac SPECT images. *Eur J Nucl Med Mol Imaging* **48**, 3457–3468 (2021). <https://doi.org/10.1007/s00259-021-05319-x>
- Zhu, F., Wang, G., Zhao, C. et al. Automatic reorientation by deep learning to generate short-axis SPECT myocardial perfusion images. *J. Nucl. Cardiol.* **30**, 1825–1835 (2023). <https://doi.org/10.1007/s12350-023-03226-2>